



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS  
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

**A DINÂMICA DO USO E OCUPAÇÃO DA TERRA NO LAGO POPÓO  
(BOLÍVIA) ENTRE 1985 E 2017 UTILIZANDO CLASSIFICAÇÃO  
VOLTADA AO OBJETO EM DADOS LANDSAT**

**Florença das Graças Moura**

MONOGRAFIA

BRASÍLIA

2018



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS  
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

**Florença das Graças Moura**

**A DINÂMICA DO USO E OCUPAÇÃO DA TERRA NO LAGO POPÓO  
(BOLÍVIA) ENTRE 1985 E 2017 UTILIZANDO CLASSIFICAÇÃO  
VOLTADA AO OBJETO EM DADOS LANDSAT**

**Monografia de especialização em  
Geoprocessamento Ambiental apresentada a  
banca examinadora do Instituto de Geociências  
como exigência para a obtenção do título de  
especialista em Geoprocessamento**

**Aprovada em 09/03/2018**

**BANCA EXAMINADORA**

Prof. Dr. Tati Almeida (orientadora) \_\_\_\_\_

Prof. Dr. Paulo Roberto Meneses \_\_\_\_\_

Prof<sup>ª</sup>. Dr. Jérémie Garnier \_\_\_\_\_

Md           Moura, Florença  
              A DINÂMICA DO USO E OCUPAÇÃO DA TERRA NO LAGO POPÓO  
              (BOLÍVIA) ENTRE 1985 E 2017 UTILIZANDO CLASSIFICAÇÃO  
              VOLTADA AO OBJETO EM DADOS LANDSAT / Florença Moura;  
              orientador Tati Almeida. -- Brasília, 2018.  
              28 p.

              Monografia (Especialização - Especialização -  
              Geoprocessamento Ambiental) -- Universidade de Brasília,  
              2018.

              1. Lago Poópo. 2. Classificação do uso e ocupação do solo.  
              3. Envi FX. 4. Classificadores Automáticos. 5. Classificação  
              Orientada a Objetos. I. Almeida, Tati, orient. II. Título.

"A verdadeira coragem é ir atrás de seu sonho mesmo quando todos dizem que ele é impossível."

**Cora Coralina**

## **AGRADECIMENTOS**

Primeiramente, a minha orientadora Tati Almeida, por ser essa pessoa tão querida e por ter confiado e acreditado em mim neste último ano.

A minha família por sempre me apoiar e compreender minha ausência, a minha mãe Raquel, meu pai Orlando e meu irmão Matheus.

Ao Guilherme, pelo incentivo a fazer a especialização e por todo o amor e carinho.

Ao Álvaro, pela paciência e ajuda em todo o andamento deste trabalho.

A UnB, pelo apoio institucional. A todos os professores e servidores do curso, em especial a Rejane, Henrique Roig e Serjão.

Aos amigos de Brasília, que por muito tempo dividiram comigo um lar, Caio Ress, Edu, Watylla, Tutão, Claudia e Fifty.

A Jane, por me seder um espacinho da sua casa toda vez que precisei voltar a Brasília.

Aos amigos da especialização, Boi (dupla), Filipy, Obama, S , Paulinha e Raina.

Aos amigos da Bahia. Ana, Jessica e Ane que foram minha família por quatro meses. Sandro, por mostrar que a vida tem que ser levada de forma mais leve. Walder, Cesar e Viana, pelos ensinamentos geológicos.

Aos amigos de Araxá, Mateusinho, Matheus, Yorrán, Marina, Mariana, Isa, Bruno, Carol M. e Carol C.

A Deus, por mostrar o caminho.

Muito obrigada a todos.

## SUMÁRIO

1. Introdução .....	7
2. Artigo.....	8
3. Conclusões e Sugestões .....	28

## 1. INTRODUÇÃO

Este trabalho consiste da monografia obrigatória para a conclusão do curso de Geoprocessamento Ambiental da Universidade de Brasília, sendo esta desenvolvida na estrutura de um artigo que foi submetido na Revista Geociências - Unesp.

A monografia está estruturada em três capítulos:

- Capítulo 1: Introdução
- Capítulo 2: Artigo - Comparação de classificadores automáticos utilizando imagens do landsat-5 e landsat-8 e a dinâmica do uso e ocupação da terra na sub-bacia p6 do lago popóo – bolívia
- Capítulo 3: Conclusões e Sugestões

A área de estudo é a sub-bacia P6 do Lago Poopó, localizada na porção sudoeste da Bolívia. Este lago vem passando por uma forte seca nos últimos anos, e esta perda de área úmida causa grande preocupação, pois condena a fauna e a flora nativa e gera o êxodo de comunidades que sobrevivem do lago.

Estudos com informações sobre a dinâmica do uso da terra, na região do Lago Poopó, ainda são escassos, apesar de fundamentais para o direcionamento e o planejamento dos recursos hídricos na região.

Desta forma este trabalho terá como objetivos principais:

- Testar classificadores automáticos (SVM, KNN e MaxVer), de modo a verificar qual desses algoritmo apresenta o melhor desempenho na área de estudo;
- Elaborar os primeiros mapas de uso e ocupação para a região da sub-bacia P6 do Lago Poopó, com o intuito de melhor compreender a dinâmica da cobertura da terra nas últimas três décadas (1985 a 2017) na área.

## 2. ARTIGO

### **A DINÂMICA DO USO E OCUPAÇÃO DA TERRA NO LAGO POÓPO (BOLÍVIA) ENTRE 1985 E 2017 UTILIZANDO CLASSIFICAÇÃO VOLTADA AO OBJETO EM DADOS LANDSAT**

**Florença das Graças MOURA<sup>1</sup>, Álvaro Xavier FERREIRA<sup>1</sup>, Tati ALMEIDA<sup>1</sup>, Jérémie GARNIER<sup>1</sup>, Frédéric SATGÉ<sup>1</sup>, Marie Paule BONNET<sup>2</sup>**

<sup>(1)</sup> Instituto de Geociências, Universidade de Brasília, Campus Universitário Darcy Ribeiro, Instituto Central de Ciências - Ala Central, Asa Norte. CEP: 70919-970. Brasília – DF. Endereços eletrônicos: fmouraunb@gmail.com, alvaroxavier.f@gmail.com, tati\_almeida@unb.br, garnier@unb.br, frederic.satge@gmail.com

<sup>(2)</sup> Espace Développement (ESPACE-DEV) (UMR,IRD),34000 Montpellier, France. Endereço eletrônico: Marie-paule.bonnet@ird.fr

Introdução  
 Área de Estudo  
 Materiais e Métodos  
 Resultado e Discussões  
     Desempenho dos Algoritmos de Classificação  
     Mapeamento do Uso e Ocupação do Solo  
 Conclusão  
 Referências Bibliográficas

**RESUMO** - O lago Poópo é o segundo maior lago da Bolívia e atualmente vem passando por uma forte crise hídrica que alguns autores associam diretamente a mudança de uso e ocupação do solo. Neste trabalho foi realizada a classificação do uso e ocupação do solo na sub-bacia P6 do lago. Inicialmente, foi analisado o desempenho dos classificadores SVM (Support Vector Machines), KNN (K-Nearest Neighbor) e MaxVer (Máxima Verossimilhança). A classificação que obteve melhor acurácia foi a gerada pelo classificador SVM, onde o valor do índice Kappa foi de 82,28% e 83,7% para as imagens Landat-5 e Landsat-8, respectivamente, e a exatidão global foi de 92% para ambas as imagens. Com as classificações do uso e ocupação do solo entre os anos de 1985 a 2017 foi verificado que as maiores alterações se deram nas classes de vegetação nativa, agricultura e área úmida. A perda de área úmida na sub-bacia vem ocorrendo desde 1995, 15 anos antes do aumento das atividades agrícolas na área, que começou a partir de 2010, diferentemente de todo o Altiplano, que apresentou o “boom” da agricultura no começo dos anos 2000. Assim, diversos fatores além das atividades antrópicas podem estar contribuindo com a aceleração da seca do Lago Poópo.

**Palavras-Chave:** Lago Poópo, Classificação do uso e ocupação do solo, Envi FX, Classificadores Automáticos, Classificação Orientada a Objetos.



**ABSTRACT:** The Poópo Lake is the second largest lake in Bolivia and is currently undergoing a severe water crisis. This work makes a classification of the use and occupation of land in P6 sub-basin of the lake. Initially, the performance of the algorithms was analyzed: SVM (Support Vector Machines), KNN (K-Nearest Neighbor) e MaxVer (Maximum-Likelihood). The classification with better accuracy was performed by the SVM algorithm, where the Kappa index value was 82.28% and 83.7% for Landat-5 and Landsat-8 images respectively, and Global Accuracy was 92% for both images. With the classification of the use and occupation between 1985 and 2017, it was verified that the most significant changes occurred in the native vegetation, agriculture and wetland areas. The loss of wetland area in the sub-basin has been occurring since 1995, 15 years before the increase in agricultural activities, which started of 2010, different from the entire Altiplano that presented the agricultural "boom" in the early 2000s. Thus, different factors such as local climatic and anthropic activities may be contributing to the drought acceleration of Poópo Lake.

**Keywords:** Poópo Lake, Classification of the use and occupation of land, Envi FX, Automatic Classifiers, Object-Oriented Classification.

## INTRODUÇÃO

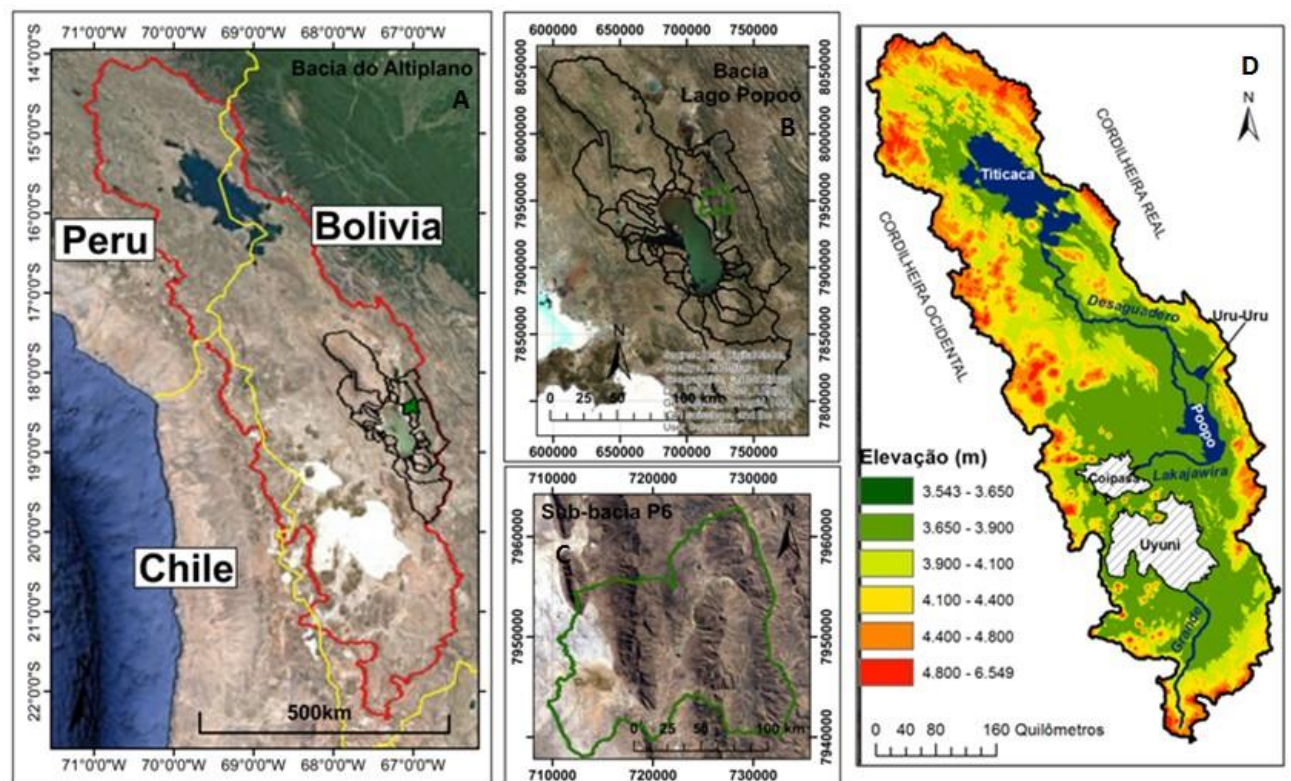
O uso e ocupação inadequados do solo podem comprometer a integridade das bacias hidrográficas (Restrepo et al. 2017, Turner et al., 2007, Donatio et al., 2005). A agricultura extensiva e a remoção parcial ou total da vegetação nativa, por exemplo, pode acelerar o processo natural de lixiviação e erosão do solo que leva ao assoreamento dos corpos d'água, além de aumentar a disponibilidade de água a processos de evapotranspiração (Blaikie e Brookfield, 2015; Bommarco et al., 2013). A compreensão da dinâmica do uso da terra é de fundamental importância para a gestão dos recursos naturais, pois a falta de planejamento assim como o mal-uso do solo, pode alterar todo o ciclo hidrológico de uma área (Small et al. 2001).

A utilização de imagens de sensores remotos na obtenção das classificações de uso e ocupação do solo para o monitoramento de recursos naturais tem resultados consolidados na literatura (Nunes & Roig, 2014; Blaschke e Kux, 2007). Os avanços tecnológicos na área de sensoriamento remoto nos últimos anos têm possibilitado a aquisição cada vez mais precisa e detalhada das informações de imagens de satélite. Os sensores atuais possuem melhores

resoluções espaciais, espectrais, radiométricas e temporais, permitindo a extração mais precisa de informação (Sano et al., 2009).

As metodologias para a extração de informações utilizando imagens devem ser sistematicamente testadas para replicação em diferentes sensores e áreas geográficas (Meneses & Almeida, 2012). A utilização de técnicas de classificação de imagens orientada ao objeto veem mostrados resultados promissores no mapeamento do uso da terra com imagens de média resolução espacial e espectral (Luz et al., 2010; Fernandes et al. 2012). A vantagem dessa técnica de interpretação automática de imagens é o aumento da produtividade e precisão do trabalho, bem como na redução da subjetividade do resultado (Camargo et al., 2012).

Nesse sentido, esse trabalho pretende utilizar técnicas de classificação voltada ao objeto para mapear a variação temporal do uso e ocupação do solo a fim de subsidiar o entendimento do colapso hídrico em curso no Lago Poópo (Figura 1). O lago é o segundo maior lago da Bolívia e uma importante fonte de água para a população, no entanto, veem passando por uma forte crise hídrica desde 2010 com períodos de seca completa.



**Figura 1:** (a) Mapa de localização (a) da Bacia do Altiplano (b) da Bacia do Lago Poopó (c) da Subbacia P6 (d) mapa de elevação indicando a localização dos principais lagos (Titicaca e Poopó), rios (Desaguadero, Lakajawi e Grande) e salares (Coipasa e Uyuni) do altiplano (modificado de Setgé, 2017).

Assim, inicialmente essa pesquisa avaliou o desempenho dos classificadores MaxVer (Máxima Verossimilhança) para a classificação supervisionada e os algoritmos SVM (*Support Vector Machines*) e KNN (*K-Nearest Neighbor*) para classificação orientada a objeto em imagens do sensor *Operational Land Imager* (OLI) do satélite Landsat-8 e do sensor *Thematic Mapper* (TM) do satélite Landsat-5 nessa região. Em um segundo momento, foi realizado o mapeamento de uso e ocupação do solo da região da sub- bacia P6 do Lago Poopó na Bolívia nos últimos 30 anos para assim compreender como se deu a dinâmica de ocupação na área.

## ÁREA DE ESTUDO

A bacia hidrográfica do Lago Poopó, situada nos Andes boliviano, faz parte da bacia endorreica do Altiplano (Figura 1) e tem uma área de aproximadamente 15.000 km<sup>2</sup>. O lago é pouco profundo, apresentando uma média de 1,08 m, sendo a maior entrada de água feita pelo rio Desaguadero (60% do total) e a saída se dá por um exutório na porção sul do Lago Poopó na direção dos salares de Coipasa e de Uyuni pelo rio Lakajawira (Figura 1d). Entretanto, há anos não é registrada a saída de água do lago para os salares (Satge, 2017).

O clima da região é semiárido com menor precipitação (200 a 750 mm/ano) que evapotranspiração (1.500 mm/ano), esta ocorrendo majoritariamente nos corpos d'água superficiais (Satgé, 2017; Pillco et al., 2007; Garreaud et al., 2003). Desse modo, pequenas variações no balanço hídrico podem impactar fortemente a região.

A área de estudo, em que foram testados os classificadores e gerado o mapeamento de uso e ocupação do solo, é uma sub- bacia do Lago Poopó, denominada P6, que apresenta 355,6 km<sup>2</sup> e está situada na porção central da bacia hidrográfica do lago. A área apresenta representatividade no contexto da região por possuir áreas naturais (água, sedimento e vegetação nativa) e agricultáveis.

## MATERIAIS E MÉTODOS

A cena que recobre a sub-bacia P6 é a 233/73 e, para o estudo de comparação dos classificadores, foram escolhidas as imagens do sensor TM de 06 de Julho de 2003 e do sensor OLI do satélite Landsat-8 de 04 de Maio de 2015. A segunda etapa do trabalho, a análise temporal do uso e ocupação do solo utilizou imagens adquiridas nos anos de 1985, 1990, 1995, 2000, 2005 e 2010 do satélite Landsat-5 e dos anos de 2015 e 2017 do satélite

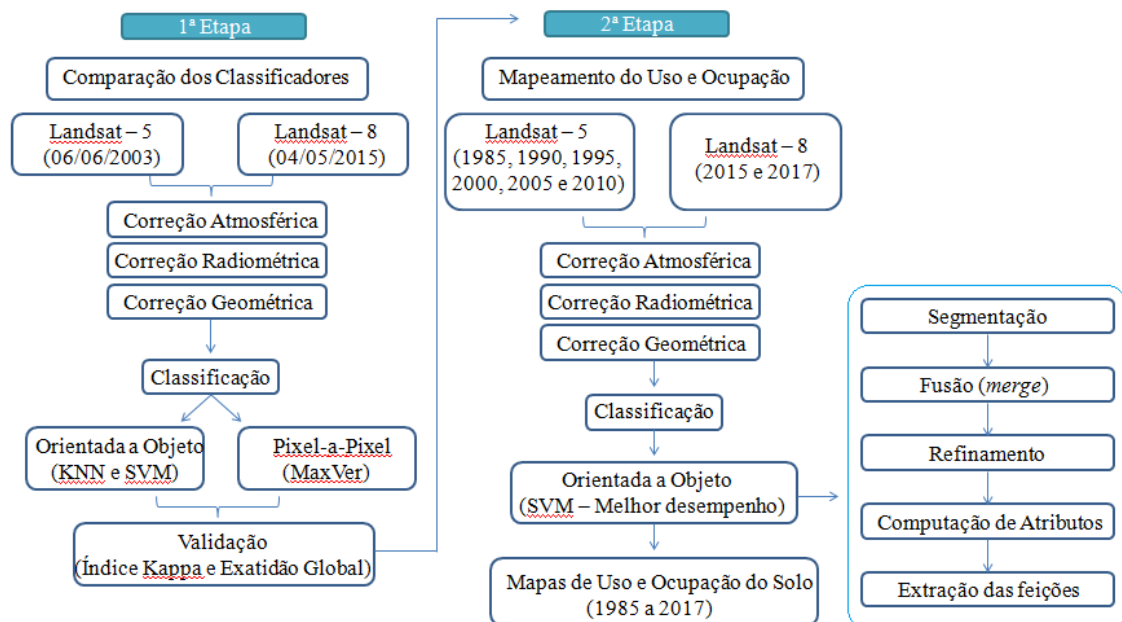
Landsat-8 (Tabela 1). Todas as imagens foram adquiridas gratuitamente pelo site *Earth Explorer* do Serviço Geológico dos Estados Unidos (USGS).

As classes consideradas no mapeamento da cobertura da terra abrangeram vegetação nativa, área exposta, água, agricultura e sedimento de rejeito, a escolha das classes foi devida a grande representatividade dessas na área da sub-bacia, assim como em toda a bacia do Lago Pópo.

**Tabela 1:** Datas das imagens utilizadas para o mapeamento temporal do Uso e Ocupação do Solo na sub-bacia P6.

OLI/Landsat 8	TM/Landsat 5
16/05/2017	06/05/2010
04/05/2015	08/05/2005
	10/05/2000
	27/04/1995
	29/04/1990
	20/05/1985

A avaliação da variação temporal do uso e ocupação do solo nessa sub-bacia foi realizada em duas etapas (figura 2). A primeira etapa consistiu na avaliação de classificadores e limiares para a definição de uma metodologia com alto grau de assertividade. Na segunda etapa foi realizada, a partir do resultado da primeira fase, a classificação das imagens.



**Figura 2:** Fluxograma de trabalho

O pré-processamento envolveu rotinas de correções radiométrica, atmosférica e geométrica. A correção atmosférica foi realizada por meio do *fast line-of-sight atmospheric*

*analysis of spectral hypercubes* (FLAASH) que utiliza o código de transferência radiativa *moderate resolution transmittance* (ModTran) para a conversão das radiâncias em reflectâncias na superfície terrestre (Adler-Golden *et al.*, 1999; Berk *et al.*, 2002; Fernandes *et al.*, 2012).

Na primeira etapa foram testados os classificadores pixel-a-pixel MaxVer e a ferramenta *Feature Extraction* (FX - ENVI). O MaxVer é um dos classificadores mais eficiente pois considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos (INPE, 2008). As amostras para treinamento (ROI) do classificador MaxVer foram definidas com base em padrões característicos de cada classe (vegetação nativa, área exposta, água, agricultura e sedimento de rejeito).

A ferramenta *Feature Extraction* possibilita extrair informações de objetos específicos de interesse através da classificação por segmentação orientada ao objeto com base nas características espaciais, texturais e espectrais das imagens pancromáticas ou multiespectrais. São ao todas cinco distintas etapas: (i) segmentação, (ii) fusão (*merge*), (iii) refinamento, (iv) computação de atributos e (v) extração das feições por regras ou por exemplos (ENVI, 2008).

A segmentação é o processo de particionamento de uma imagem em objetos pelo agrupamento de pixels vizinhos, com valores comuns (Harris Geospatial Solutions, 2018) e quanto mais efetiva for a segmentação, melhor serão os resultados da classificação (Campos *et al.*, 2013). Nas imagens da série LANDSAT processadas nesse trabalho foram utilizadas o algoritmo *Edge* que, segundo *Harris Geospatial Solutions* (2018), melhor segmenta objetos que possuem arestas. Os limiares de cada ano encontram-se listados na tabela 2.

**Tabela 2:** Limiares utilizados na segmentação das imagens para cada ano.

Segment Setting							
2017	2015	2010	2005	2000	1995	1990	1985
40	40	30	40	25	40	40	40

A etapa de fusão teve como princípio agrupar os segmentos gerados por similaridade e adjacência. O algoritmo “*Full Lambda Schedule*” combinou pequenos segmentos em áreas maiores e texturizadas e foi utilizado na pesquisa com limiar de 10 para todas as imagens nessa etapa. Tanto para a segmentação quanto para a fusão os limiares foram escolhidos após uma detalhada avaliação visual das imagens que recobrem a área. Nesse trabalho os atributos espaciais, texturais e espectrais, foram explorados e utilizados em sua totalidade ou apenas parcialmente (maior relevância) (Tabela 3).

**Tabela 3:** Tabela dos atributos que o ENVI FX utilizada para a classificação dos segmentos (\*os atributos espectrais e texturais são aplicadas para todas as bandas das imagens)

<b>Espacial</b>	<b>Espectral*</b>	<b>Textural*</b>
Área	Mínima (Spectral Min)	Escala (Texture Range)
Comprimento	Máxima (Spectral Max)	Média (Texture Mean)
Compacidade	Média (Spectral Mean)	Variância (Texture variance)
Convexidade	Std (Spectral Std)	Entropia (Texture Entropy)
Solidez		
Esfericidade		
Fator		
Elongação		
Forma Retangular		
Direção Principal		
Maior Comprimento		
Menor Comprimento		
Número de buracos		
Área de buracos/Área solida		

A extração dos objetos foi realizada utilizando “exemplos”, assim, a classificação foi realizada a partir de um processo que associa dados desconhecidos, a uma ou mais feições conhecidas (ENVI, 2008; Nunes & Roig, 2014). Os dados de treinamento consistiram em objetos (segmentos) selecionados como amostras representativas das classes de vegetação natural, sedimento de rejeito, água, área exposta e agricultura. Para cada classe foi coletado uma quantidade representativa de exemplos para servirem de base para o algoritmo classificar automaticamente o restante da imagem.

Os algoritmos testados para a classificação de toda a imagem foram o KNN (*K-Nearest Neighbor*) e SVM (*Support Vector Machine*). O KNN é um classificador onde o aprendizado é baseado na analogia. O conjunto de treinamento é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimensional (Gnecco et al., 2005). O SVM é embasado pela teoria de aprendizado estatístico, essa teoria estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização, definidos como a sua capacidade de prever corretamente a classe de novos dados do mesmo domínio em que o aprendizado ocorreu (Lorena e Carvalho, 2007).

As avaliações da metodologia de maior assertividade nas imagens de 2003 (Landsat 5/ TM) e 2015 (Landsat 8/ OLI) utilizando classificação pixel-a-pixel e por segmentação foram realizadas com a análise da qualidade da classificação de acordo com o índice Kappa (de Landis e Kock, 1977) e a Exatidão Global (Jensen, 1996), a partir das matrizes de confusão. A escolha das datas das imagens utilizadas na análise comparativa de classificadores teve como premissa básica o período em que o *Google Earth* apresentava o melhor recobrimento na

região. Para a validação foram gerados 200 pontos na área da sub-bacia e essas amostras foram geradas de forma aleatória com o apoio da ferramenta “*Create Random Points*” no *software* ArcMap 10.3 e validadas no *Google Earth*.

Assim, após a avaliação estatística foi elaborada a metodologia e replicada nas imagens entre 1985 e 2017 resultando na classificação de uso e ocupação do solo dos últimos 30 anos.

A segunda etapa da pesquisa resultou na geração de oito imagens classificadas que foram comparadas entre si para o entendimento da dinâmica espaço temporal da sub-bacia P6.

## RESULTADOS E DISCUSSÕES

### DESEMPENHO DOS ALGORITMOS DE CLASSIFICAÇÃO

A etapa de avaliação do desempenho dos algoritmos de classificação SVM, KNN e Maxver nas imagens TM e OLI (2003 e 2017, respectivamente) foi realizada utilizando os parâmetros apresentados na seção metodológica desse trabalho. Em relação as classificações utilizando o SVM e KNN foram realizados testes na parte de segmentação com a utilização de todos os atributos espaciais, texturais e espectrais e com a utilização somente dos atributos de maior relevância utilizando como apoio a ferramenta de autoseleção do programa; os atributos que foram selecionados para cada imagem encontram-se nas tabelas 4.

**Tabela 4:** Tabela dos atributos que o Envi FX (ferramenta de autoseleção) selecionou para a classificação.


TM/L5 - 2003		
Espectral		Textural
Mínima (Spectral Min) B1,B2,B3,B4,B5,B7		Escala (Texture Range) B5,B7
Máxima (Spectral Max) B2,B3,B3,B5,B7		Média (Texture Mean) B1,B2,B3,B4,B5,B7
Média (Spectral Mean) B1,B2,B3,B4,B5,B7		Variância (Texture variance) B4,B5,B7
Std (Spectral Std) B1,B5,B7		Entropia (Texture Entropy) B1,B2,B3,B4,B5,B7
OLI/L8 - 2015		
Espacial	Espectral	Textural
Maior Comprimento	Mínima (Spectral Min)	Escala (Texture Range)
Comprimento	B1,B2,B3,B4,B5	B1,B2,B3,B4,B5,B6,B7
Fator (From Factor)	Máxima (Spectral Max)	Média (Texture Mean)
	B2,B3,B3,B5,B7	B1,B2,B3,B4,B5,B6,B7
	Média (Spectral Mean)	Variância (Texture variance)
	B1,B2,B3,B4,B5,B6,B7	B5,B6
	Std (Spectral Std)	Entropia (Texture Entropy)
	B5,B6,B7	B5,B6

O resultado do índice kappa e da exatidão global das classificações (Tabela 5), gerados a partir das matrizes de confusão, mostra que o classificador digital que apresentou melhor acurácia foi o SVM, utilizando somente os atributos de maior relevância para a classificação das imagens. De acordo com Landis e Kock (1977), os valores do índice Kappa, indicam que a qualidade de todas as classificações geradas é de muito boa a excelente. Mas segundo Anderson *et al.*, 2001, a exatidão global das classificações geradas pelo classificador MaxVer não apresentou valor aceitável (mínimo admissível  $\geq 0,85$ ).

**Tabela 5:** Resultados das validações das classificações. KNN<sup>1</sup> e SVM<sup>1</sup> utilizando todos os atributos e KNN<sup>2</sup> e SVM<sup>2</sup> utilizando os atributos selecionados.


<b>Índice Kappa</b>					
	<b>KNN<sup>1</sup></b>	<b>KNN<sup>2</sup></b>	<b>SVM<sup>1</sup></b>	<b>SVM<sup>2</sup></b>	<b>MAXVER</b>
<b>L5</b>	78,76	79,65	79,32	83,7	67,94
<b>L8</b>	79,15	82,27	81,64	82,28	69,82
<b>Exatidão Global</b>					
	<b>KNN<sup>1</sup></b>	<b>KNN<sup>2</sup></b>	<b>SVM<sup>1</sup></b>	<b>SVM<sup>2</sup></b>	<b>MAXVER</b>
<b>L5</b>	87,5	89,5	89,5	92	83,5
<b>L8</b>	88,5	90,5	90	92	83

As classificações geradas nas imagens do sensor OLI/Lansat-8 e TM/Landsar-5 apresentaram variações sutis para todos os algoritmos utilizados (Figura 3 e 4), demonstrando que os classificadores se comportaram de forma semelhante para ambas as imagens. A área de estudo é muito acidentada e desta forma a imagem apresenta uma grande quantidade de sombras, assim para a classificação toda a região sombreada foi caracterizada como vegetação nativa.



**Figura 3:** Gráfico dos valores do Índice Kappa encontrados nas imagens Landsat-5 e Landsat-8. KNN<sup>1</sup> e SVM<sup>1</sup> utilizando todos os atributos e KNN<sup>2</sup> e SVM<sup>2</sup> utilizando os atributos selecionados.





**Figura 4:** Gráfico dos valores da Exatidão Global encontrados nas imagens Landsat-5 e Landsat-8. KNN¹ e SVM¹ Utilizando todos os atributos e KNN² e SVM² utilizando os atributos selecionados.

A análise das matrizes de confusão (tabela 6 e 7) para cada classificação indica que as classes melhor definidas foram áreas expostas, bacias de sedimentação de rejeito e água. As maiores inconsistências foram observadas para as classes destinadas à agricultura e a vegetação nativa, provavelmente associadas ao comportamento espectral semelhante dessas classes. A associação de atributo de “forma” na classificação reduz a confusão, mas ainda torna a classificação dessa classe muito duvidosa.

O algoritmo de melhor qualidade na classificação e que apresentou a menor confusão entre as classes foi a que utilizou o algoritmo SVM com a seleção de atributos, o que coincide com os resultados do índice kappa e da exatidão global. O alto desempenho do SVM, com baixo erro de classificação das classes se deve à robustez e capacidade de formar planos  $n$ -dimensionais deste método (Garofalo et al., 2015).

**Tabela 6:** Matrizes de confusão das classificações geradas na imagem Landsat – 8

<b>KNN (todos os atributos)</b>						
2015 (OLI/L8)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>116</b>		9			125
Área Exposta		<b>38</b>	2			40
Agricultura	4		<b>14</b>			18
Água				<b>0</b>		0
Sedimento	6	1	1		<b>9</b>	17
TOTAL	126	39	26	0	9	<b>200</b>
<b>KNN (atributos selecionados)</b>						
2015(OLI/L8)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>120</b>		12		2	134
Área Exposta		<b>34</b>				34
Agricultura	2		<b>19</b>		1	22
Água				<b>0</b>		0
Sedimento	2				<b>8</b>	10
TOTAL	124	34	31	0	11	<b>200</b>
<b>SVM (todos os atributos)</b>						
2015(OLI/L8)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>116</b>		14		2	132
Área Exposta	1	<b>40</b>				41
Agricultura	2		<b>21</b>		1	24
Água				<b>0</b>		0
Sedimento					<b>3</b>	3
TOTAL	119	40	35	0	6	<b>200</b>
<b>SVM (atributos selecionados)</b>						
2015(OLI/L8)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>136</b>		11			147
Área Exposta	1	<b>25</b>				26
Agricultura	3		<b>19</b>		1	23
Água				<b>0</b>		0
Sedimento					<b>4</b>	4
TOTAL	140	25	30	0	5	<b>200</b>
<b>MaxVer</b>						
2015(OLI/L8)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>108</b>		17		5	130
Área Exposta	2	<b>27</b>	2			31
Agricultura	4	1	<b>26</b>		1	32
Água				<b>0</b>		0
Sedimento	2				<b>5</b>	7
TOTAL	116	28	45	0	11	<b>200</b>

**Tabela 7:** Matrizes de confusão das classificações geradas na imagem Landsat-5.

<b>KNN (todos os atributos)</b>						
2003 (TM/L5)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>106</b>		12		2	120
Área Exposta	1	<b>35</b>				36
Agricultura	5	1	<b>26</b>		1	33
Água				<b>1</b>		1
Sedimento	3				<b>7</b>	10
TOTAL	115	36	38	1	10	<b>200</b>
<b>KNN (atributos selecionados)</b>						
2003 (TM/L5)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>127</b>	1	9		1	138
Área Exposta		<b>43</b>				43
Agricultura	1		<b>11</b>			12
Água	2			<b>0</b>		2
Sedimento	2				<b>3</b>	5
TOTAL	132	44	20	0	4	<b>200</b>
<b>SVM(todos os atributos)</b>						
2003 (TM/L5)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>123</b>		15		2	140
Área Exposta		<b>32</b>				32
Agricultura	3		<b>21</b>			24
Água				<b>0</b>		0
Sedimento	1				<b>3</b>	4
TOTAL	127	32	36	0	5	<b>200</b>
<b>SVM (atributos selecionados)</b>						
2003 (TM/L5)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>122</b>		15		2	139
Área Exposta		<b>39</b>	1			40
Agricultura	1	2	<b>16</b>			19
Água				<b>0</b>		0
Sedimento					<b>2</b>	2
TOTAL	123	41	32	0	4	<b>200</b>
<b>MaxVer</b>						
2003 (TM/L5)	Veg. Nativa	Área Exposta	Agricultura	Água	Sedimento	TOTAL
Veg. Nativa	<b>117</b>		23		3	143
Área Exposta	1	<b>33</b>				34
Agricultura	3	2	<b>17</b>		1	23
Água				<b>0</b>		0
Sedimento					<b>0</b>	0
TOTAL	121	35	40	0	4	<b>200</b>

A classificação orientada a objetos é aplicada sistematicamente em imagens de alta resolução espacial (Zhou *et al.*, 2008); no entanto, os resultados obtidos demonstram que a metodologia para imagens de média resolução espacial apresenta resultados superiores as classificações pixel-a-pixel.

## MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO


Após o teste dos algoritmos e a análise estatística da validação do índice Kappa e da Exatidão Global, verificou-se que o melhor algoritmo é o SVM utilizando a seleção automática de atributos do *software*, portanto foi este algoritmo, com o apoio da ferramenta de autoseleção de atributos, que foi utilizado para a classificação de uso e ocupação do solo nos anos de 1985, 1990, 1995, 2000, 2005, 2010, 2015 e 2017. Os atributos que o *software* selecionou automaticamente para cada imagem se encontram na tabela 8.

**Tabela 8:** Tabela dos atributos que o Envi FX (ferramenta de autoseleção) selecionou para a classificação de todos os anos.

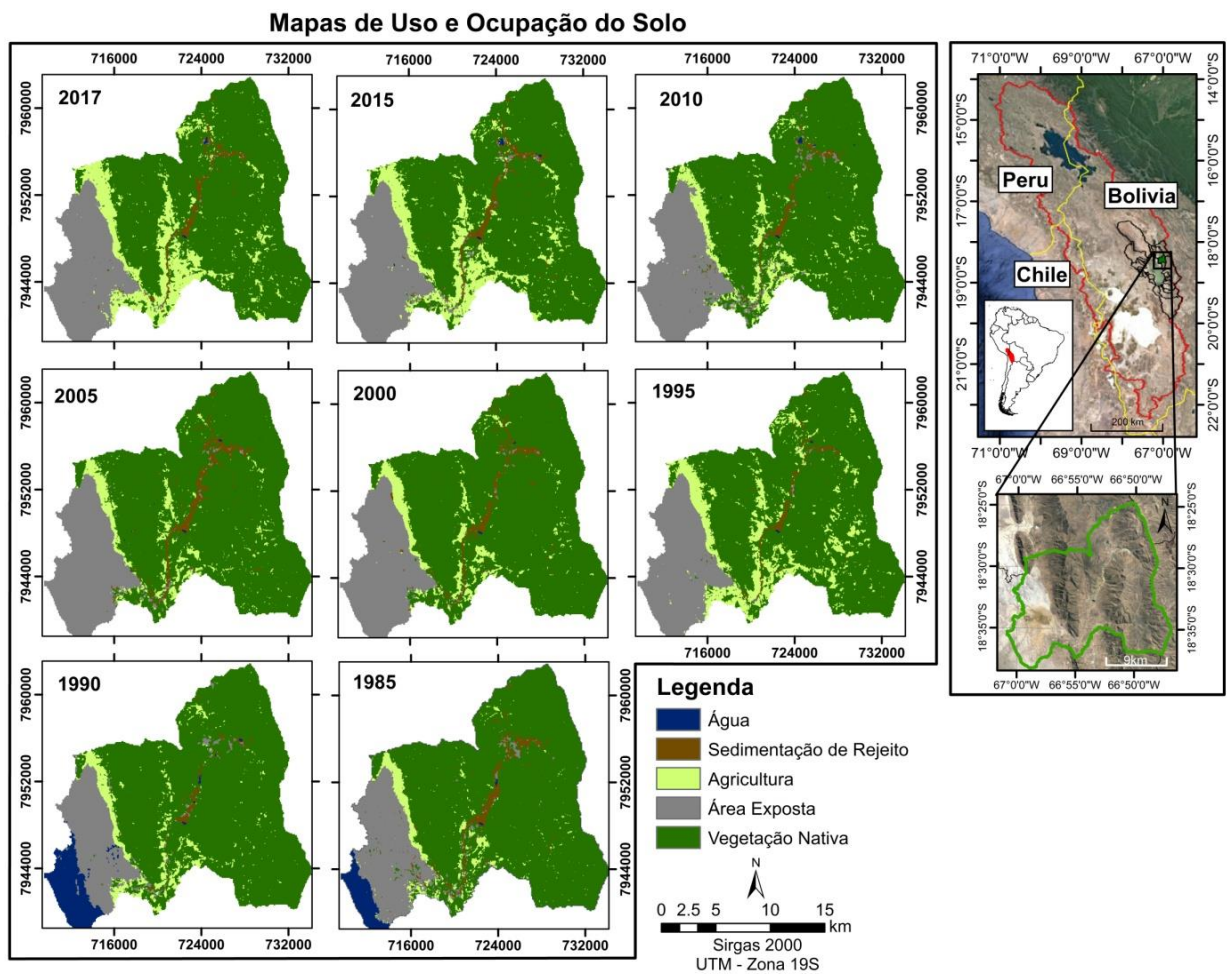
2017		
Espacial	Espectral	Textural
	Mínima (Spectral Min) B1,B2,B3,B4,B6,B7	Escala (Texture Range) B3,B4,B5
	Máxima (Spectral Max) B1,B2,B3,B4,B5,B6,B7	Média (Texture Mean) B1,B2,B3,B4,B5,B6,B7
	Média (Spectral Mean) B1,B2,B3,B4,B5,B6,B7	Variância (Texture variance) B3,B5,B7
	Std (Spectral Std) B2,B6,B7	Entropia (Texture Entropy) B5,B6
2015		
Espacial	Espectral	Textural
Maior Comprimento	Mínima (Spectral Min) B1,B2,B3,B4,B5	Escala (Texture Range) B1,B2,B3,B4,B5,B6,B7
Comprimento	Máxima (Spectral Max) B2,B3,B3,B5,B7	Média (Texture Mean) B1,B2,B3,B4,B5,B6,B7
Fator (From Factor)	Média (Spectral Mean) B1,B2,B3,B4,B5,B6,B7	Variância (Texture variance) B5,B6
	Std (Spectral Std) B5,B6,B7	Entropia (Texture Entropy) B5,B6
2010		
Espacial	Espectral	Textural
Compacidade	Mínima (Spectral Min) B4,B5,B7	Escala (Texture Range) B1,B2,B3,B4,B5,B7
Convexidade	máxima (Spectral Max) B1,B2,B5,B7	Média (Texture Mean) B2,B4,B5,B7
Esfericidade	Média (Spectral Mean) B3,B4,B5,B7	Variância (Texture variance) B4
Fator (From Factor)	Std (Spectral Std) B1,B4,B5,B7	Entropia (Texture Entropy) B1,B2,B3,B4,B5,B7
Forma Retangular		
2005		
Espacial	Espectral	Textural
Elongação	Mínima (Spectral Min) B4,B5,B7	Escala (Texture Range) B1,B2,B3,B4,B5,B7
	máxima (Spectral Max) B1,B2,B5,B7	Média (Texture Mean) B2,B4,B5,B7
	Média (Spectral Mean) B3,B4,B5,B7	Variância (Texture variance) B4
	Std (Spectral Std) B1,B4,B5,B7	Entropia (Texture Entropy) B1,B2,B3,B4,B5,B7

<b>2000</b>		
<b>Espacial</b>	<b>Espectral</b>	<b>Textural</b>
Esfericidade	Mínima (Spectral Min)	Escala (Texture Range)
Elongação	B1,B2,B3,B4,B5,B7	B1,B5,B7
	máxima (Spectral Max)	Média (Texture Mean)
	B1,B2,B3,B4,B5,B7	B1,B2,B3,B4,B5,B7
	Média (Spectral Mean)	Variância (Texture variance)
	B1,B2,B3,B4,B5,B7	B4
	Std (Spectral Std)	Entropia (Texture Entropy)
	B5,B7	B1,B2,B3,B4,B5
<b>1995</b>		
<b>Espacial</b>	<b>Espectral</b>	<b>Textural</b>
Solidez	Mínima (Spectral Min)	Escala (Texture Range)
Esfericidade	B1,B2,B3,B4,B5,B7	B1,B2,B3,B5,B7
Maior direção	máxima (Spectral Max)	Média (Texture Mean)
	B4,B7	B1,B2,B3,B4,B5,B7
	Média (Spectral Mean)	Variância (Texture variance)
	B3,B4,B5,B7	B7
	Std (Spectral Std)	Entropia (Texture Entropy)
	B1,B2,B3,B4,B5,B7	B2,B3,B4,B7
<b>1990</b>		
<b>Espacial</b>	<b>Espectral</b>	<b>Textural</b>
Solidez	Mínima (Spectral Min)	Escala (Texture Range)
Esfericidade	B1,B2,B3,B4,B5,B7	B1,B2,B3,B4
Maior direção	máxima (Spectral Max)	Média (Texture Mean)
	B1,B4	B1,B3,B4,B5,B7
	Média (Spectral Mean)	Variância (Texture variance)
	B1,B4,B5	B3,B4,B7
	Std (Spectral Std)	Entropia (Texture Entropy)
	B1,B2,B3,B4	B1,B2,B3,B4
<b>1985</b>		
<b>Espacial</b>	<b>Espectral</b>	<b>Textural</b>
Comprimento	Mínima (Spectral Min)	Escala (Texture Range)
Esfericidade	B1,B2,B3,B4,B5,B7	B3
Maior direção	máxima (Spectral Max)	Média (Texture Mean)
Menor Comprimento	B1,B2,B3,B4,B5,B7	B1,B2,B3,B4,B5,B7
	Média (Spectral Mean)	Variância (Texture variance)
	B1,B2,B3,B4,B5,B7	B7
	Std (Spectral Std)	Entropia (Texture Entropy)
	B2,B3	B1,B2,B4,B4,B5,B7

Os resultados das classificações (Figuras 5 e 6) indicam que a classe vegetação nativa é a predominante na sub-bacia P6 do Lago Popoó, incluem-se nessa classe vegetação de montanha e estepe (vegetação típica dos Andes, formada basicamente por gramíneas), atualmente esta classe representa 65,91% (234,45 km<sup>2</sup>) do total da área da sub-bacia, mas em 1985 representava 73,66% (262,02 km<sup>2</sup>). Essa cobertura natural foi substituída principalmente por áreas de agricultura. Em 2017 a agricultura representou 13,52% (48,10 km<sup>2</sup>) da sub-bacia, valor este muito superior, quando se comparada a 1985 em que essa classe correspondia apenas 5% (15,44km<sup>2</sup>) do total da área (Tabela 9). Essas áreas de vegetação nativa são importantes, pois confere a proteção ao solo, diminuindo a velocidade de escoamento superficial e favorecendo a infiltração de água no solo.



**Figura 5:** Gráfico indicando a representatividade de cada classe (em %) nos mapas de uso e ocupação do solo.




**Figura 6:** Mapas de Uso e Ocupação do Solo na sub-bacia do Lago Poópo de 1985 a 2017

**Tabela 9:** Área que cada classe ocupa no mapa de Uso e Ocupação do Solo.

	<b>Agricultura</b>	<b>Área Exposta</b>	<b>Água</b>	<b>Vegetação Nativa</b>	<b>Sedimento</b>	<b>355,66</b>
<b>2017</b>	48,10 (13,5%)	66,40 (18,7%)	0,21 (0,06%)	234,45 (65,9%)	6,50 (1,8%)	
<b>2015</b>	41,43 (11,6%)	69,42 (19,5%)	0,39 (0,11%)	236,22 (66,4%)	8,20 (2,3%)	
<b>2010</b>	23,96 (6,7%)	74,49 (20,9%)	0,37 (0,10%)	250,75 (70,5%)	6,09 (1,7%)	
<b>2005</b>	19,27 (5,4%)	69,96 (19,7%)	0,20 (0,05%)	255,55 (71,8%)	10,68 (3,0%)	
<b>2000</b>	19,24 (5,4%)	67,33 (18,9%)	0,11 (0,03%)	260,13 (73,1%)	8,85 (2,5%)	
<b>1995</b>	15,65 (4,4%)	72,19 (20,3%)	0,12 (0,03%)	261,66 (73,6%)	6,04 (1,7%)	
<b>1990</b>	20,40 (5,7%)	49,49 (13,9%)	21,86 (0,03%)	260,85 (73,3%)	3,07 (0,9%)	
<b>1985</b>	15,44 (4,3%)	52,70 (14,8%)	14,99 (6,14%)	262,02 (73,7%)	10,51 (2,9%)	

A classe água também apresentou uma grande variação temporal, em 2017 representava apenas 0,06% (0,216 km<sup>2</sup>) do total da área da sub-bacia, entretanto em 1985 representava 6% (14,99 km<sup>2</sup>) deste total; simultaneamente a essa perda de massa d'água, houve o aumento da classe de área exposta que passou de 14,81% (52,70km<sup>2</sup>) em 1985, para 18,67% (66,40 km<sup>2</sup>) em 2017. A área de sedimentação de rejeito na região de estudo (incluída na classe de área exposta) é oriunda principalmente das atividades de mineração, esta classe foi a que apresentou a menor variação ao longo dos anos.

Em toda a bacia do altiplano o “boom” da quinoa começou no início dos anos (Satgé, 2017). Entretanto ao analisar a dinâmica do uso da terra na sub-bacia P6, o aumento das áreas agrícolas começou após 2010 e a perda de área úmida na região de estudo vem ocorrendo desde 1995 (Figura 7a), 15 anos antes do aumento das atividades agrícolas e diminuição das áreas de vegetação nativa na sub-bacia. (Figura 7b). Desta forma, diversos fatores podem estar contribuindo com essa redução acelerada dos corpos de água, como por exemplo, as variações climáticas locais e as atividades antrópicas como a mineração, a extração de água subterrânea e superficial de forma desordenada e a agricultura em outras regiões da bacia do lago Poopó que interfere no ciclo hidrológico de forma regional.



**Figura 7:** Gráficos de dispersão (%) (a) comparando a classe agricultura com a água (c) comparando a classe vegetação nativa com agricultura.

## CONCLUSÃO

1. As classificações voltada ao objeto utilizando os algoritmos SVM e KNN, são mais eficientes que a classificação supervisionada pixe-a-pixel MaxVer; sendo o classificador SVM com atributos de maior relevância com desempenho superior ao KNN;
2. Os valores do índice Kappa e da Exatidão Global, indicam que a qualidade das classificações geradas pelos classificadores SVM e KNN é de muito boa a excelente. Desta forma, classificou com exatidão as cinco classes previamente definidas para a sub-bacia P6 do Lago Poopó, e viabilizou a obtenção da caracterização de uso e cobertura do solo;
3. A região de estudo em 2017 apresentou aproximadamente 65,9% de sua área coberta de vegetação nativa, 13,5% por agricultura, 0,06% de corpos d'água, 18,74% de área exposta e 1,8% da área representa sedimentação de rejeito;
4. A redução da área da classe “água” vem ocorrendo desde 1995, 15 anos antes do aumento significativo das atividades agrícolas e diminuição das áreas de vegetação nativa que foi potencializada após 2010;
5. Diversos fatores podem estar contribuindo com a aceleração da perda de água no lago, como, por exemplo, as variações climáticas locais e as atividades antrópicas como a mineração, a extração de água subterrânea e superficial de forma desordenada e a agricultura em outras regiões da bacia do lago Poopó que interfere no ciclo hidrológico de forma regional.



## REFERÊNCIAS BIBLIOGRÁFICAS

- ADLER-GOLDEN. S.M.; MATTHEW. M.W.; BERNSTEIN. L.S.; LEVINE. R.Y.; BERK. A.; RICHTSMEIER. S.C.; ACHARYA. P.K.; ANDERSON. G.P.; FELDE. G.W.; GARDNER. J.; HOKE. M.; JEONG. L.S.; PUKALL. B.; MELLO. J.; RATKOWSKI. A.; BURKE. H.-H. Atmospheric correction for short-wave spectral imagery based on MODTRAN4. Proceedings of the Society of Photo-Optical Instrumentation Engineers. v.3753. p.61-69. 1999.
- ANDERSON. J.F.; HARDY. E.E.; ROACH. J.T.; WITMER R.E. A land use and land cover classification system for use with remote sensor data. U.S. Geological Survey Professional Paper 964. Washington: U.S. Geologic Survey.2001. 41p (paper 964).
- BERK. A.; ADLER-GOLDEN. S.M.; RATKOWSKI. A.; FELDE. G.W.; ANDERSON. G.P.; HOKE. M.L.; COOLEY. T.; CHETWYND. J.H.; GARDNER. J.A.; MATTHEW. M.W.; BERNSTEIN. L.S.; ACHARYA. P.K.; MILLER. D.; LEWIS. P. Exploiting MODTRAN radiation transport for atmospheric correction: the FLAASH algorithm. In: INTERNATIONAL CONFERENCE ON INFORMATION FUSION. 5.. 2002. Annapolis. Proceedings. Annapolis: ISIF. 2002. v.2. p.798-803.
- CAMARGO. F.F.; ALMEIDA.C.M.; COSTA. G.A.O.P.; FEITOSA. R.Q.; OLIVEIRA. D.A.B.; HEIPKE. C.; FERREIRA. R.S. An open source object-based framework to extract landform classes. v. 39. n. 1. p. 541-554. 2012.
- CAMPOS. A.R.. FONSECA. D.R.. SAMPAIO. D.M.. FARIA. S.D.. ELMIRO. M.A.T. Classificação orientada a objeto para mapeamento do uso e cobertura do solo do município de Rio Acima - MG: por crescimento de regiões e por extração de objetos. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR. Foz do Iguaçu. PR. Brasil. 13 a 18 de abril de 2013. INPE
- CUSICANQUI. J.. K. DILLEN. M. GARCIA. S. GEERTS. D. RAES. AND E. MATHIJS. 2013. "Economic Assessment at Farm Level of the Implementation of Deficit Irrigation for Quinoa Production in the Southern Bolivian Altiplano." In *Spanish Journal of Agricultural Research*. 11:894. doi:10.5424/sjar/2013114-4097.
- DI PACE. F.T.. SILVA. B.B.. SILVA. V.P.R.. SILVA. S.T.A. "Mapeamento do saldo de radiação com imagens Landsar 5 e modelo de elevação digital." R. Bras. Eng. Agríc. Ambiental. v.12. n.4. p.385-392. 2008.
- DONATIO. N. M. M.; GALBIATTI. J. A.; DE PAULA. R. C. Qualidade da água de nascentes com diferentes usos do solo na bacia hidrográfica do córrego Rico. São Paulo. Brasil. Engenharia Agrícola. v.25. n.1. p.115-125. 2005.
- ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE (ESRI). ArcGis Professional Gis for desktop, versão 10.3, 2018.
- ENVI. ENVI FEATURE EXTRACTION MODULE: User's guide. [S.L.]: ITT visual information solution. 2008.
- FERNANDES. R.R.. NUNES. G.M.. SILVA. T.S.F. "Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia" . Pesq. agropec. bras.. Brasília. v.47. n.9. p.1251-1260. set. 2012

- GARREAUD, RENÉ. MATHIAS VUILLE. and Amy C. Clement. 2003. "The Climate of the Altiplano: Observed Current Conditions and Mechanisms of Past Changes." *Palaeogeography. Palaeoclimatology. Palaeoecology* 194 (1–3): 5–22. doi:10.1016/S0031-0182(03)00269-4.
- GAROFALO, D.F.T., MESSIAS, C.G., LIESENBERG, V., BOLFE, E. L., FERREIRA, M. C. "Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático." *Pesq. agropec. bras.*, Brasília, v.50, n.7, p.593-604, jul. 2015 DOI: 10.1590/S0100-204X2015000700009
- GNECCO, BRUNO BARBERI.. Um Sistema de Visualização Imersivo e Interativo de Apoio ao Ensino de Classificação de Imagens. disponível em <http://www.di.ufpb.br/liliane/publicacoes/wrv2001-cave-final.pdf>. acesso em 25/05/2005.
- HARRIS GEOSPATIAL SOLUTIONS. EXTRACT FEATURE. Disponível em <<http://www.harrisgeospatial.com/docs/ExtractFeatures.html>>. Acesso em Fevereiro de 2018.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) - Manuais: tutorial de geoprocessamento SPRING. 2008.
- JACOBSEN, S.-E.. 2011. The Situation for Quinoa and Its Production in Southern Bolivia: From Economic Success to Environmental Disaster. *J. Agron. Crop Sci.* 197. 390–399. <https://doi.org/10.1111/j.1439-037X.2011.00475.x>
- JENSEN, J.R.. 1996. Introductory digital image processing: a remote sensing perspective. Prentice-Hall. Upper Saddle River, NJ. 318 p
- LANDIS, J.R. & KOCK, G. G. The measurement of observer agreement for categorical data. *Biometrics*. 33: 159-75. 1977.
- Lorena a.c., Carvalho a.c.p.l.f. Uma introdução às Support Vector Machines. *RITA* . Volume XIV . Número 2 . 2007
- LUZ, N.B. DA; ANTUNES, A.F.B.; TAVARES JÚNIOR, J.B. Segmentação multirresolução e classificação orientada a objetos aplicados a imagens Spot-5 para o mapeamento do uso da terra. *Floresta*. v.40. p.429-446. 2010
- MCKEE, T. B., N. J. DOESKEN, AND J. KLEIST. 1993: The relationship of drought frequency and duration of time scales. Eighth Conference on Applied Climatology. American Meteorological Society, Jan17-23, 1993, Anaheim CA. pp.179-186.
- MENESES, P. R.; ALMEIDA, T. D. (Organizadores). Introdução ao Processamento de Imagens de Sensoriamento Remoto. Universidade de Brasília. Brasília. 2012. 266 p.
- NUNES, F.N. E ROIG,H. L. "Análise e Mapeamento do Uso e Ocupação do Solo da Bacia do Alto do Descoberto, DF/GO, por meio de classificação automática baseada em regras e lógica nebulosa." *Revista Árvore*. Viçosa-MG. v.39. n.1. p.25-36. 2015. Dóí: 10.1590/0100-67622015000100003.
- ROCHE, M.A., J. BOURGES, J. CORTES, AND R. MATTOS. 1992. *Climatología E Hidrología de La Cuenca Del Lago Titicaca*. Edited by C Dejoux and A. Iltis. Boston: Springer Netherlands. doi:10.1007/978-94-011-2406-5\_4.

- SANO. E.E.; ROSA. R.; BRITO. J.L.S.; FERREIRA. L.G; BEZERRA. H.S. Mapeamento da cobertura vegetal natural e antrópica do bioma Cerrado por meio de imagens Landsat ETM+. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO. 14.. 2009. Natal. Anais... Natal: INPE. 2009. p.1199-1206.
- SATGÉ. Frédéric Christophe. 2017. "Recursos Hídricos Do Altiplano Andino : Contribuição Do Sensoriamento Remoto."
- SIMÕES. A.J. Determinação da evapotranspiração potencial e necessidade de água de irrigação para o projeto de Mandacant. Petrolina. PE..s. ed.. 1973. 29p.
- PILLCO R. CINTIA B.U. AND LARS B. 2007. "Precipitation Variability and Regionalization over the Southern Altiplano . Bolivia." *International Journal of Climatology*. 149–64.
- VUILLE. M. D R HARDY. B BRAUN. F KEIMIG. AND R S BRADLEY. 1998. "Atmospheric Circulation Anomalies Associated with 1996/1997 Summer Precipitation Events on Sajama Ice Cap. Bolivia." *Journal of Geophysical Research* 103 (98): 191–204. doi:10.1029/98JD00681.
- YAN. G.; MAS. J.-F.; MAATHUIS. B.H.P.; XIANGMINN. Z.;VAN DIJK. P.M. Comparison of pixel-based and object-oriented image classification approaches – a case study in a coal fire area. Wuda. Inner Mongolia.China.International Journal of Remote Sensing. v.27. p.4039-4055. 2006.
- ZHOU. W.T. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. International Journal of Remote Sensing. 2008. Vol. 29. p. 3119 – 3135.

### 3. CONCLUSÕES E SUGESTÕES

O presente trabalho mostra a importância do sensoriamento remoto para estudos em regiões isoladas e com poucos recursos. Esta monografia faz parte de um projeto maior e diversos são os estudos que ainda estão em desenvolvimento em todo o altiplano região essa que atualmente passa por uma grande crise hídrica. Além das conclusões já mencionadas no capítulo anterior é importante mencionar alguns pontos fundamentais a serem estudados no futuro:

- Análise climática local na sub-bacia P6.
- Gerar classificações de uso e ocupação do solo para toda a bacia do Lago Poopó, desde a década de 80, para assim verificar se o uso da bacia como um todo apresenta a mesma resposta que a sub-bacia P6;
- Fazer a classificação do uso e ocupação do solo de ano em ano para melhor compreender a dinâmica da terra, tanto na sub-bacia P6 como em toda a bacia do lago Poopó;
- Fazer a classificação do uso e ocupação da terra na região utilizando imagens de alta resolução para uma melhor exatidão;
- Estudos sobre os aquíferos na região também são de fundamental importância para ter um melhor entendimento de todo o ciclo hidrológico da área.